

SISTEMAS AUTÓNOMOS

El aprendizaje automático resuelve la supervisión de los revestimientos de molinos

Para evitar que se desprenda mineral de los tambores de los molinos, se insertan revestimientos reemplazables. ABB y la Universidad de Ciencias Aplicadas de Berna han desarrollado un sistema de supervisión del desgaste de los revestimientos basado en acelerómetros y aprendizaje automático que permite identificar el mejor momento para cambiar el revestimiento, reduciendo así los costes de inactividad.

—
Venkat Nadipuram
ABB process Industries,
Mining, Aluminium and
Cement Baden-Daettwil,
Suiza

venkat.nadipuram@
ch.abb.com

—
Marco Jordi
Prof. Dr. Axel Fuerst
Instituto de la Universidad
de Ciencias Aplicadas
de Berna para Sistemas
Industriales Inteligen-
tes, i3s
Burgdorf, Suiza

En las minas grandes, el mineral se tritura in situ para extraer minerales valiosos. Los molinos que realizan esta extracción constan de un tambor grande en el que el propio mineral, y a veces también unas bolas de acero añadidas, llevan a cabo el proceso físico de trituración. A medida que el tambor gira, el mineral/las bolas se elevan por el lado del interior del tambor mediante paletas hasta el ángulo en cascada, desde donde caen para chocar contra el fondo, reduciendo el mineral.

Dado que el diámetro del tambor puede alcanzar hasta los 10 m, el tambor es una pieza costosa. Para evitar daños al tambor, se insertan revestimientos metálicos o de goma. El coste de sustitución de los revestimientos es alto debido al tiempo de inactividad del molino y a las piezas de sustitución, por lo que lo más económico es cambiar el revestimiento lo más tarde posible, pero también en un momento en el que se minimice la pérdida de producción. Para lograr este objetivo, es importante conocer el desgaste real del revestimiento. El desgaste puede medirse desde dentro del molino, pero para ello es necesario incurrir en una costosa parada de producción. Por lo tanto, es deseable un método que permita detectar el desgaste durante el funcionamiento →1.

Supervisión de las vibraciones

Cuando el mineral golpea el revestimiento, se producen vibraciones. Se ha demostrado que estas vibraciones y su función de transferencia cambian según el espesor del revestimiento y es en este efecto en el que subyace un método prometedor para medir el desgaste. En consecuencia, ABB y

el Instituto de Sistemas Industriales Inteligentes (I3S) de la Universidad de Ciencias Aplicadas de Berna llevaron a cabo simulaciones transitorias y de respuesta armónica para investigar este comportamiento. Los resultados mostraron claramente que la amplitud de la señal de aceleración de un revestimiento desgastado es mayor que la de un revestimiento nuevo.

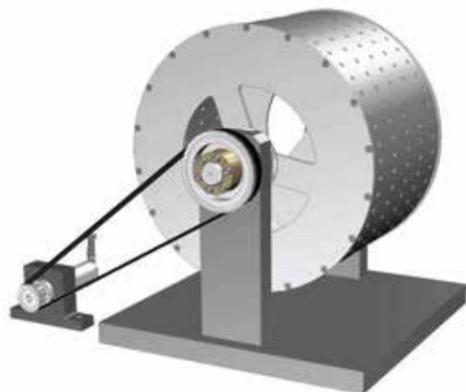
—
Resulta económico cambiar el revestimiento lo más tarde posible, pero también en un momento en el que se minimice la pérdida de productividad.

Para verificar estos hallazgos y porque el acceso a un molino de mineral real es difícil, se construyó un modelo a escala de un molino →2. Con este prototipo, ABB e I3S realizaron muchas mediciones experimentales con distintos espesores de revestimientos. Todos los datos de medición se analizaron con redes neuronales profundas y se clasificaron con una gran precisión en las clases de desgaste correctas.

Para transferir este proceso del laboratorio a un entorno de molino real, se realizaron mediciones en un molino de mineral real. Con estos datos, I3S y ABB desarrollaron un prototipo que permitió medir el estado del revestimiento y los parámetros de proceso de un molino que deben medirse durante su funcionamiento.

—
01 La supervisión del desgaste del revestimiento en equipos de molino de alto rendimiento es fundamental para maximizar el tiempo de actividad del proceso. La imagen muestra el molino de la mina Boliden en Garpenberg, Suecia, con actividad minera desde al menos 375 AC. Este molino contribuye a la cifra de producción de la mina de 2,5 millones de toneladas de mineral al año.





02a

Desgaste del revestimiento

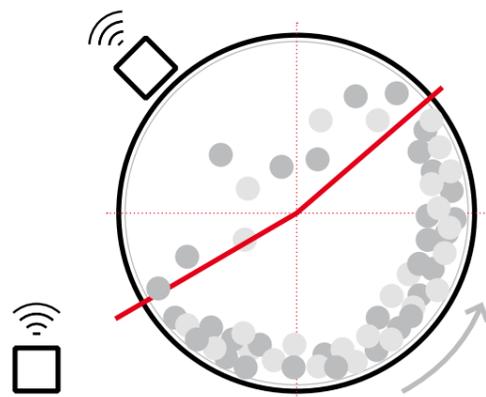
La medición del espesor del revestimiento se realizó indirectamente mediante sensores de aceleración en la superficie exterior del tambor del modelo a escala.

La señal en bruto de estos sensores se procesó para extraer características que una red neuronal profunda pudiera utilizar para reconocer patrones. La red de reconocimiento de patrones o «patternent» utilizada incluye una capa de entrada, tres capas ocultas con 500 neuronas cada una y una capa de salida para clasificar el espesor del revestimiento.

Los resultados mostraron una precisión muy alta (cerca del 98 %) en las mediciones del modelo a escala, es decir, solo el 2 % de los conjuntos de datos de medición se clasificaron erróneamente.

Se utilizó esta configuración para clasificar los datos a partir tanto del modelo a escala como de las pruebas de campo. En el laboratorio, se simuló siete estados distintos del revestimiento en el modelo a escala. Los espesores del revestimiento de 2 a 17 mm y las diferentes cargas reflejan estos estados. El objetivo era clasificar la señal en bruto previamente procesada en una de las siete clases correspondientes. Los resultados mostraron una precisión muy alta (cerca del 98 %) en las mediciones del modelo a escala. solo el 2 % de los conjuntos de datos de medición se clasificaron erróneamente. Esto refleja los resultados del aprendizaje (70 %) y del conjunto de datos de prueba (30 %). →4 muestra la matriz de confusión de la clasificación. Además, los datos que no están correctamente clasificados aparecen cerca de la diagonal de la matriz, lo que significa que el error de clasificación es pequeño.

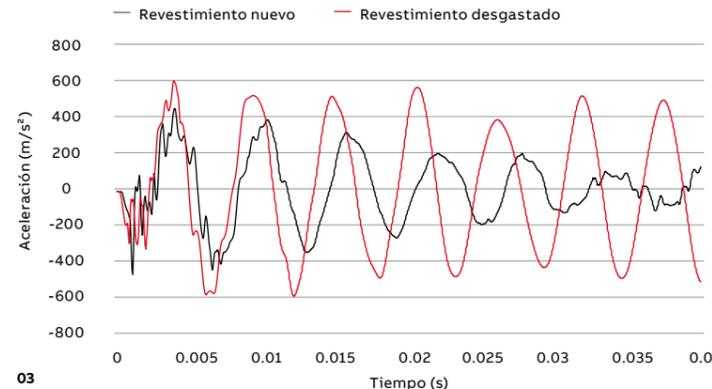
Los resultados de las mediciones de las pruebas de campo también mostraron una buena precisión. Caba esperar que la precisión fuera significativamente menor en este caso debido a los efectos ambientales, pero con una red neuronal profunda adaptada basada en Tensorflow [2] se obtuvo una precisión relativamente alta del 82,9 %. El objetivo es mejorar aún más la precisión con más datos.



02b

Simulaciones

La simulación de respuesta armónica y transitoria con el método de elementos finitos (FEM) en ANSYS [1] de modelos de revestimiento nuevos y desgastados reforzó la idea de que existe una diferencia medible en la señal de aceleración del revestimiento causada por el impacto del mineral en la pared del tambor entre un revestimiento nuevo y un revestimiento desgastado. Por ejemplo, las frecuencias procedentes de un revestimiento desgastado son mayores que las de un revestimiento nuevo. De hecho, a medida que la goma se desgasta, las propiedades de amortiguación disminuyen. Las principales diferencias medibles en las simulaciones se encuentran en las amplitudes →3. Esto se correlaciona con la teoría de que una fina capa de goma provoca un impacto más fuerte, lo que da lugar a mayores fuerzas de excitación.



03

02 Modelo a escala

02a Modelo a escala de un molino autógeno para mediciones experimentales en laboratorio. El modelo consta de un tambor de acero, un accionador con una correa dentada conectada a un pequeño motor eléctrico. El interior del tambor está recubierto con una capa de goma intercambiable para simular el revestimiento.

2b Esquema funcional del modelo a escala con ángulo de pie y hombro y sensor de aceleración WLAN. El sensor se coloca en la superficie exterior del tambor para medir la vibración. La señal de aceleración es la variable dependiente; el grosor del revestimiento y la carga del molino son variables independientes; y las revoluciones, la temperatura, el tamaño y la calidad de la piedra son variables controlables. Se realizaron diferentes mediciones con un espesor de revestimiento de 2 a 17 mm y una carga del molino de 1 a 4 kg. Para cada condición, se realizaron al menos dos mediciones de aceleración de 2 minutos con una frecuencia de muestreo de 970 Hz.

03 Señales de aceleración simuladas procedentes de la simulación transitoria de un revestimiento nuevo y un revestimiento desgastado. La señal de aceleración del revestimiento desgastado presenta amplitudes y frecuencias más altas procedentes de una amortiguación menor.

Ángulos de pie y hombro

Para determinar el ángulo de la cascada dentro del molino de mineral, se utilizaron los datos de la señal de aceleración de un giro del molino real. En →5 puede verse la señal de aceleración de una rotación. En la zona de impacto, donde las piedras golpean el revestimiento, se aprecian grandes amplitudes. Además, en la región del ángulo de hombro, cuando las piedras abandonan el revestimiento, se aprecian cambios en la señal. Esto se debe a que, en la zona del ángulo de hombro, los trozos de mineral están sueltos unos encima de otros. El vector de la gravedad cambia en relación con la posición del mineral y el mineral empieza a

abandonar el lecho de roca deslizándose hacia el centro del lecho de roca, creando vibraciones en la carcasa del molino.

Para averiguar los ángulos de pie y hombro, se calcula la entropía de información de la señal. La entropía de la señal (a lo largo de una ventana móvil determinada) representa la cantidad de información contenida en la señal [3]. En otras palabras, cuanto más aleatoria e impredecible sea la señal de aceleración debido a los impactos, mayor será su entropía. Gracias a este cálculo, se pueden detectar cambios en la señal de aceleración y, por lo tanto, en los ángulos de pie y hombro. Un parámetro importante es la longitud de la ventana del índice calculado. Para estos datos, una longitud de ventana de 1180 muestras arroja buenos resultados.

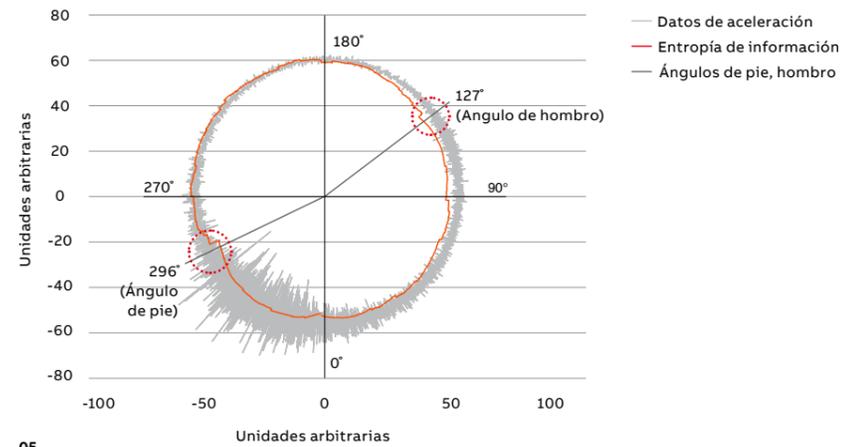
Con una red neuronal profunda adaptada basada en Tensorflow, los resultados de las mediciones de pruebas de campo también arrojaron una precisión relativamente alta: 82,9 %.

Matriz de confusión All

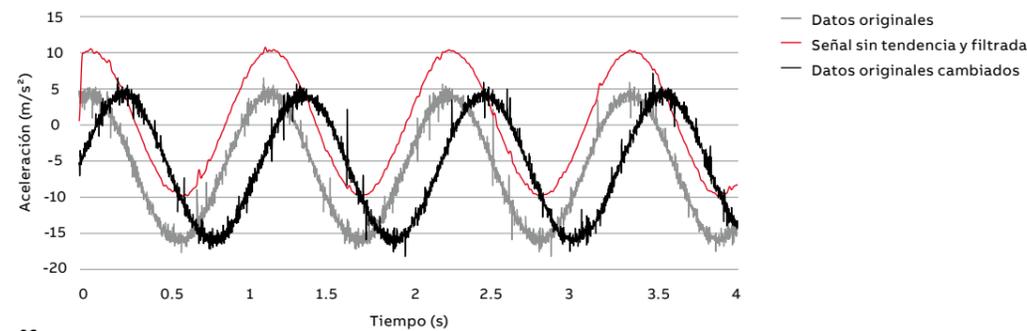
	1	2	3	4	5	6	7	
1	159 14.2%	0 0.0%	0 0.0%	1 0.1%	0 0.0%	1 0.1%	1 0.1%	98.1% 1.9%
2	0 0.0%	159 14.2%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	1 0.1%	99.4% 0.6%
3	0 0.0%	0 0.0%	160 14.3%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	100% 0.0%
4	0 0.0%	0 0.0%	0 0.0%	153 13.7%	0 0.0%	5 0.4%	1 0.1%	96.2% 3.8%
5	0 0.0%	0 0.0%	0 0.0%	0 0.0%	153 13.7%	1 0.1%	3 0.3%	97.5% 2.5%
6	1 0.1%	0 0.0%	0 0.0%	6 0.5%	0 0.0%	153 13.7%	1 0.1%	95.0% 5.0%
7	0 0.0%	1 0.1%	0 0.0%	0 0.0%	7 0.6%	0 0.0%	153 13.7%	95.0% 5.0%
	99.4% 0.6%	99.4% 0.6%	100% 0.0%	95.6% 4.4%	95.6% 4.4%	95.6% 4.4%	95.6% 4.4%	97.3% 2.7%
	1	2	3	4	5	6	7	

04

04 Matriz de confusión para la clasificación del espesor del revestimiento en siete clases (2, 5, 7, 10, 12, 15, 17 mm) a partir de las mediciones realizadas en el modelo a escala del molino.



05



06

Pruebas de campo

Para verificar los modelos matemáticos se realizaron pruebas de campo. El delicado equipo de sensores se protegió contra el duro y sucio entorno del molino mediante una robusta caja metálica. El equipo incluye una batería, un temporizador, varios accionadores de los sensores de aceleración, un convertidor analógico-digital y un dispositivo de adquisición de datos. Los propios sensores de aceleración se montaron con imanes directamente sobre el tambor del molino y sus cables se conectaron a la caja. La caja se montó en un molino totalmente operativo y se dejó recogiendo datos durante varias semanas.

La señal en bruto de la vibración es muy ruidosa debido a los numerosos impactos registrados mientras gira el molino, por lo que es necesario volver a procesar los datos en bruto.

Análisis de los datos con técnicas de aprendizaje automático

La señal en bruto de la vibración es muy ruidosa debido a los numerosos impactos registrados mientras gira el molino y es difícil distinguir entre los distintos estados del revestimiento. Por lo tanto, es necesario realizar un procesamiento previo de los datos en bruto. Solo con una base de datos normalizada se pueden aplicar algoritmos de aprendizaje automático. A través de muchas iteraciones, se encontró el mejor modelo de clasificación.

Procesamiento previo de los datos

Dado que los puntos de partida de las mediciones no son siempre los mismos, existen diferencias entre los conjuntos de datos. Pero para una correcta evaluación, se debe disponer de una base de datos uniforme. Por este motivo, se incluyó en la configuración un detector de fases. La señal original se filtró a través de un filtro pasabajos (frecuencia de corte de 2 Hz) y luego se aplicó un ajuste de curvas y se eliminaron las tendencias. Se pudo determinar la fase de los datos filtrados y sin tendencia. A continuación, se utilizó esta fase para desplazar los datos originales de forma que todos los conjuntos de datos tuvieran el mismo punto de partida →6.

05 Gráfico polar de los ángulos del pie y hombro resultantes de una vuelta en un molino de mineral real.

06 Procesamiento previo de los datos de aceleración. La señal desplazada se calcula mediante la señal original y la señal sin tendencia y filtrada.

07 Red neuronal para la clasificación del espesor del revestimiento.

Referencias

[1] ANSYS, Academic Research Mechanical, Release 18.1, ANSYS, Inc.

[2] M. Abadi et al., "TensorFlow: Large-Scale Machine Learning on Heterogeneous Systems," libro blanco preliminar, Google, noviembre de 2015. Descarga disponible. [tensorflow.org/paper/whitepaper2015.pdf](https://arxiv.org/abs/1605.08679)

[3] S. Vajapeyam, "Understanding Shannon's Entropy metric for Information," arxiv.org, marzo de 2014. Disponible: arxiv.org/ftp/arxiv/papers/1405/1405.2061.pdf

[4] MATLAB, Neural Network Toolbox 2016a, The MathWorks, Inc., Natick, Massachusetts, Estados Unidos.

Tras el desplazador de fases, los datos de las mediciones realizadas de 2 minutos se dividieron en fragmentos que representaban una revolución de tambor. Además, se volvieron a muestrear los fragmentos en 1 024 muestras. Este procesamiento previo de los datos en bruto garantizó una base de datos consistente para el algoritmo de aprendizaje automático.

Extracción de las características

Los algoritmos de aprendizaje automático intentan mapear un conjunto de características hasta los valores objetivo correctos. La elección correcta de estas características es, pues, muy importante. Se probaron diferentes características, por ejemplo, ondas pequeñas, entropía y análisis de Fourier. El mejor resultado se consiguió con una combinación de valores estadísticos, datos en bruto de la aceleración y la FFT (Transformada rápida de Fourier) de cada fragmento. Todas estas características se combinaron en una tabla con el valor objetivo correspondiente. Esta tabla se utiliza como matriz de entrada para la red neuronal.

Creación de una red neuronal para el reconocimiento de patrones

Para clasificar los datos, se probaron diferentes métodos de aprendizaje automático, como máquinas de soporte vectorial, árboles de decisión o redes neuronales. Los mejores resultados se lograron con las redes neuronales. Una red neuronal debe reconocer patrones en cada señal. Estos patrones ayudan a clasificar la señal en una clase objetivo. Se crearon clases para todas las mediciones obtenidas a partir de los diferentes ejercicios de pruebas de carga del molino y espesor del revestimiento.

Una vez definidas las clases, se construyeron las matrices de entrada y salida de la red neuronal. La matriz de entrada incluye la tabla de características descrita anteriormente y la matriz de salida define la clase de destino correcta para cada conjunto de características. A continuación, se creó una red neuronal [4] con tres capas ocultas

con 500 neuronas cada una y una capa de salida, para su clasificación →7.

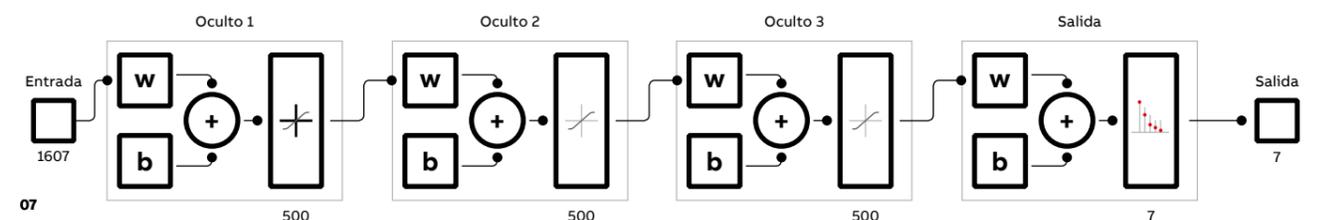
Del conjunto de datos, el 70 % se utilizó para entrenar a la red neuronal, el 15 % para validación y el 15 % para probar la red neuronal. El entrenamiento de la red consistía en una «retropropagación de gradientes conjugados escalados», en concreto, un método que actualiza los parámetros críticos del modelo (pesos y sesgos de las neuronas) a su paso de una forma iterativa. Por último, el ajuste fino de los hiperparámetros de la red (es decir, aquellos parámetros significativos que no se ajustaron en el modelo central) dio lugar a un ajuste óptimo de la red neuronal y permitió determinar con fiabilidad el estado del revestimiento.

Gracias a este sistema, los revestimientos podrán sustituirse en función de su estado, reduciendo así costes y tiempo de inactividad y ahorrando recursos.

Supervisión del revestimiento para aumentar la productividad y reducir los costes

La hipótesis de que la señal de aceleración cambia significativamente según el espesor del revestimiento se confirmó mediante simulaciones y mediciones en el modelo a escala y en un molino real.

El sistema de supervisión desarrollado por I3S y ABB muestra cómo pueden utilizarse sensores de aceleración y técnicas de aprendizaje automático para medir el estado y los parámetros de proceso de un molino durante el funcionamiento. Gracias a este sistema, los revestimientos podrán sustituirse en función de su estado, reduciendo así costes y tiempo de inactividad y ahorrando recursos. Este nuevo sistema de supervisión ayudará a los operarios de molinos a aumentar su productividad y a planificar el mantenimiento. •



07